

Präzise Vorhersage von Weichenstörungen

Verschleißverhalten besser einschätzen lernen und Fehler verlässlich vorhersagen, so dass die Instandhaltung agieren kann, bevor eine Störung auftritt.




Abb. 1: Prinzipische Skizze der RUL-Prognose und Diskretisierung

Thomas Böhm

Eine hoch verfügbare Infrastruktur ist die Voraussetzung für einen leistungsfähigen und zuverlässigen Eisenbahnverkehr. Instandhaltung ist notwendig, um Infrastrukturelemente funktionsfähig zu halten. Dies gilt insbesondere für Weichen als betrieblich essentielles, aber störanfälliges Element. Weichen erlauben einem Schienenfahrzeug nicht nur den Gleiswechsel ohne Halt, sondern sind auch eine der Hauptursachen für infrastrukturbedingte Störungen und daraus resultierende Verspätungen [1, 2]. Weichen sind also kritisch für die Betriebsqualität und die Attraktivität des Eisenbahnverkehrs, aber ihre Inspektion, Wartung und Instandsetzung sind auch teuer. Das Institut für Verkehrssystemtechnik des Deutschen Zentrums für Luft- und Raumfahrt e.V. (DLR) erforscht in Zusammenarbeit mit Bahnbetreibern Möglichkeiten, zustandsorientierte Instandhaltung bei Weichen anzuwenden. Ziel der Forschung ist es, das Verschleißverhalten besser einschätzen zu lernen und Fehler verlässlich vorherzusagen, so dass die Instandhaltung agieren kann, bevor eine Störung auftritt. Damit sollen letztlich Verspätungsminuten und Kosten reduziert werden. Um dieses Ziel zu erreichen, wird ein datengetriebener Ansatz verfolgt, bei dem kontinuierliche Überwachungsdaten der Weiche mit anderen Informationen verknüpft und mittels Big-Data-Analyseverfahren ausgewertet werden.

Aus Forschungssicht mag es wünschenswert sein, Weichen vollumfänglich mit Überwachungssensoren auszurüsten, z.B. für

Kraftmessungen entlang der Zungen, Gleislaufeigenschaften der Weiche, Verschleißspiel, Einzelstellwiderstand je Gleitstuhl etc. Aber aus wirtschaftlicher Sicht ist dies nicht sinnvoll. Die Anschaffungskosten robuster, bahntauglicher Technik wären nicht gerechtfertigt. Zudem wäre jeder Sensor für sich eine Fehlerquelle, die es zu überwachen und instandzuhalten gilt. Um möglichst anwendungsnahe Lösungen zu entwickeln, braucht es reale Felddaten einer kontinuierlichen Weichenüberwachung. Derzeit ist am Markt nur eine kleine Anzahl von Weichendiagnosesystemen für Vollbahnen verfügbar, die entsprechende Daten bei minimaler Sensorausrüstung liefern können. Die verbreitetsten Systeme sind Poss der Firma Strukton, die Roadmaster-Serie der Firma VAE und SIDS W (compact) der Firma Siemens. Sie alle messen den Stellstrom und bilden eindimensionale, singuläre Merkmale (Mittelwerte oder Integrale). Deren Über- oder Unterschreiten eines statischen Referenzwertes wird als Fehler interpretiert. Erfahrungen aus dem Feld zeigen jedoch, dass die Systeme noch keine ausreichende Lösung für eine zustandsorientierte Instandhaltung darstellen, weil vor allem die Prognose fehlt [3]. Nichtsdestotrotz sind die Stellstrommessungen eine wichtige Basis für die Prognose von Weichenstörungen. Im Folgenden wird gezeigt, wie zusätzliche Datenquellen und spezielle Data-Mining-Verfahren eine präzise Prognose ermöglichen. Es ist dabei wichtig zu verstehen, dass es sich um einen aufwendigen, iterativen Prozess handelt, bei dem die Schritte der Datenselektion, -vorverarbeitung, -transformation, Verfahrensparametrierung und

Evaluation einen größeren Anteil haben als das Mining selbst [4]. In diesem Zusammenhang geht der Artikel auch auf die Grenze des Ansatzes ein, die die zugrundeliegende Datenqualität setzt.

Was heißt präzise Prognose?

Laut VDI-Richtlinie 2651 erfolgt bei einer Prognose eine Aussage zu bevorstehenden Ausfällen oder Störungen in Form der verbleibenden Nutzungsdauer, englisch Remaining Useful Life (RUL) [5]. Eine ebenso simple Definition für den Begriff „präzise“ gibt es nicht.

Es stellt sich zuerst die Frage, in welcher Einheit die RUL vorhergesagt werden soll, um sie als präzise zu bezeichnen. Um diese zu beantworten, ist die Intention der Prognose wichtig. Es wird beabsichtigt, die Störung bzw. Verspätungen zu verhindern. Eine Vorhersage muss den Instandhaltungsverantwortlichen also genügend Zeit lassen, die betroffene Weiche zu erreichen und Instandhaltungsmaßnahmen durchzuführen, bestenfalls während einer regulären Betriebspause. Um eine Maßnahme in die Feinplanung einzubringen, sollte sie rund drei bis fünf Tage vorher angezeigt werden. Dann besteht ausreichend Vorlauf, damit Verspätungen effizient und ohne zusätzliche Kosten verhindert werden können. Das haben Gespräche mit Instandhaltungsverantwortlichen ergeben. Die Angabe der RUL in Tagen erscheint daher als gute Wahl.

Aber mit wie vielen Dezimalstellen soll die RUL angegeben werden und wie wird mit Unsicherheiten in der Prognose umgegangen? Eine zeitlich weit entfernte Störung sehr genau anzugeben ist nicht sinnvoll. Denn beispielsweise ist die Handlungsrelevanz bei 100,75 Tagen bis zur Störung nicht viel anders als bei 100,1 Tagen. Außerdem ist die Schwankungsbreite der Vorhersage umso größer, je weiter die Störung entfernt ist. Gründe dafür sind, dass zum einen die Abnutzung bzw. die Zustandsverschlechterung nicht gleichmäßig verläuft. Zum anderen beinhalten Messungen fast immer ein gewisses Rauschen. Wenn dann auch die Vorhersage schwankt, wirkt sie unzuverlässig. Aus diesem Grund wird die RUL diskretisiert, d.h. sie wird in Klassen zusammengefasst. Dabei werden Vorhersagen zu weit entfernten Störungen in größeren Zeit-

räumen zusammengekommen. Wenn ein Ausfall näher rückt, wird auch das Zeitintervall enger – allerdings nicht detaillierter als 0,0625 Tage (1,5 Stunden). Unterhalb dieses Wertes kann die Instandhaltung kaum noch reagieren. Denn eine ungeplante Notfallentstörung zur Verhinderung von Verspätungen ist eventuell nur noch möglich, wenn ein bis zwei Stunden bis zum Ausfall verbleiben. Dann ist allerdings mit erhöhten Kosten für Streckensperrungen und Bereitschaftspersonal zu rechnen. Abb. 1 skizziert das beschriebene Prinzip der RUL-Vorhersage. Als präzise Prognose wird hier also eine treffsichere Einordnung von Messgrößen in eine Klasse verstanden, die eine mindestens verbleibende Anzahl von Tagen bis zur Störung repräsentiert. Für diesen Artikel werden zwölf Klassen im Intervall von 0,0625 bis 128 Tage verwendet – RUL-Bereiche für 2(-4, -3, -2, -1, 0, 1, 2, 3, 4, 5, 6, 7) Tage.

Welche Daten werden verwendet?

Im Wesentlichen werden Daten aus vier Bereichen für die Vorhersage von Weichenstörungen kombiniert:

- Messdaten der Stellstromüberwachung,
- Klimadaten,
- Charakteristiken der Weichen sowie
- Meldungen aus SAP als Referenz für die Störung.

Stellstrommessungen stammen von 28 Weichen, die mit SIDs W [6] ausgestattet sind. Aus einem Überwachungszeitraum von zwei Jahren liegen Messdaten vor. Wichtigste Größen sind dabei arithmetische Mittelwerte der Antriebswirkleistung während verschiedener Umstellphasen (Abb. 2), die Zungenvorspannung und weitere elektrische Kennwerte.

Da die Stellstrommessungen bzw. die Weiche vom Klima beeinflusst werden, ist es wichtig, entsprechende Daten mit in die Analyse einzubeziehen [8]. So beeinflusst beispielsweise die Außentemperatur signifikant die Längsposition der Zungen gegenüber der Backenschiene (Zungenwanderung) und demzufolge den Verschluss. Mittels Korrelationsanalyse wurden die relevanten Klimaparameter Temperatur und Luftfeuchtigkeit ermittelt.

Die Bauartcharakteristiken einer Weiche, wie z.B. der Radius, die Länge, der Verschluss oder der Antrieb, sind ebenfalls sehr wichtig für die Vorhersage. Weichen unterschiedlicher Bauart verhalten sich unterschiedlich, wodurch sich auch die Stellstrommessungen differenzieren. So kann ein bestimmtes Wirkleistungsniveau bei einem Typen störungsrelevant, aber bei einem anderen Typen vollkommen normal sein. Um die relevanten Bauartcharakteristiken zu identifizieren, die mit den Stellstrommessungen in Zusammenhang stehen, und daraus Gruppen mit ähnlichem Verhalten zu bilden, wurde eine eigene Heuristik ent-




Abb. 2: Messverlauf während des Weichenumlaufs bei SIDs W (gemäß [1])

wickelt. Eine einfache Korrelationsanalyse kann nicht durchgeführt werden, weil die Bauart konstant ist, während die Stellstrommessungen eine Zeitreihe darstellen. Auch die Voraussetzungen für andere Standardverfahren (z.B. Hotellings T^2 -Test, Wilcoxon-Mann-Whitney-Test, Anova) sind nicht gegeben, da keine Normalverteilung oder gleichen Varianzen vorliegen. Die entwickelte Heuristik stellt den Zusammenhang mittels extensivem, hierarchischem Clustering und Reklassifikation her.

Als Referenz für Störungen an den Weichen wurden Aufzeichnungen aus SAP verwendet. Anhand der Standard- und Freitextmeldungen der Dokumentation wurden jene Störungen ausgeschlossen, die per se nicht über den Stellstrom zu detektieren sind. Dies betrifft beispielsweise defekte Weichenheizungen, Schienenfehler und beschädigte Radlenkerbleche. Es verbleiben 61 Einträge, die nicht weiter nach ihrer Ursache differenziert werden, hauptsächlich weil diese nicht eindeutig dokumentiert wurde.

Im Ergebnis der Datenselektion, -vorverarbeitung und einiger Transformationsschritte wurde die Anzahl prognoserelevanter Attribute von 100 auf 28 reduziert. Rund 250 000 Messungen mit diesen Attributen werden für die Prognose verwendet.

Wie erfolgt die Prognose?

Ziel der Prognose ist es, die Zeit bis zur Störung zu bestimmen. Dafür müssen Muster identifiziert werden, die eine Zuordnung der Daten zu den RUL-Klassen erlauben. Auf diese Weise kann für neue Messungen die Zeit bis zur Störung (im Rahmen der oben beschriebenen Diskretisierung) bestimmt werden. Für die Prognose stehen prinzipiell zahlreiche Verfahren zur Auswahl, etwa Regressionsverfahren, Partikelfilter, Hidden-Markov-Modelle, Entscheidungsbaumverfahren oder

künstliche neuronale Netze. Je nach zugrundeliegender Daten- und Problemstruktur eignen sich die Verfahren jeweils sehr gut bis gar nicht für eine Lösung – ein nach wie vor gültiger Grundsatz bei Data Mining, Pattern Recognition oder Machine Learning [8]. Es obliegt daher dem Know-how des Anwenders, ein geeignetes Verfahren zu wählen.

Für die hochdimensionale, nicht balancierte und nicht normalverteilte Datenbasis werden Support Vector Machines (SVM) verwendet, um Weichenstörungen zu prognostizieren. Stark vereinfacht ausgedrückt, wird der Datenraum in eine höhere Dimension transformiert, die eine mathematisch einfache Separation erlaubt. Anschließend wird eine Hyperebene berechnet, die einen maximalen Abstand zwischen Klassen definiert. Die Grenzen werden durch die Stützvektoren (Support Vectors) beschrieben. Für eine detaillierte Erklärung zu SVM wird die Literaturquelle [9] empfohlen. Der Vorteil von SVM ist, dass sie unempfindlich für Datenausreißern und Überanpassung sind. Nachteilig sind dagegen ihre Rechenintensivität, der hohe Parametrierungsaufwand und der Umstand, dass die Vektoren für den Menschen kaum lesbar bzw. interpretierbar sind. Gerade der Aufwand für die Wahl einer passenden Transformationsfunktion (Kernel-Funktion) und der passenden Parameter ist erheblich, aber entscheidend für das Ergebnis. Trotz dieser Umstände werden SVM favorisiert, weil sie im Vergleich mit anderen Methoden die besten Ergebnisse zeigten.

Von allen Messdaten werden 70 % für das Training verwendet, also dem Finden der Stützvektoren für die jeweilige RUL-Klasse. Mit dem so gebildeten Modell wird anschließend jeder bisher unbekannten Messung der verbleibenden 30 % eine RUL zugewiesen, unter Berücksichtigung von Bauart und Klimabedingungen.

Welche Ergebnisse werden erreicht?

Die Prognose gelingt unterschiedlich gut. Bei einigen Störungen kann die mindestens verbleibende Zeit bis zur Störung zuverlässig bestimmt werden. Ein Beispiel dafür zeigt Abb. 3, in der die prognostizierte RUL mit der tatsächlichen verglichen wird. Im Verlauf der letzten 64 Tage bis zur dokumentierten Störung ist die Zuordnung der 1215 Datensätze zu einer RUL-Klasse treffsicher, bis auf wenige Ausreißer. Gibt das Prognosemodell beispielsweise die Klasse mit 32

Tagen an, so bleibt der Instandhaltung noch mindestens dieser Zeitraum, um gegen die sich entwickelnde Störung vorzugehen.

Abb. 4 zeigt ein gegenteiliges Ergebnis für 2263 Datensätze einer anderen Weiche mit einer anderen Störung. Hier schwankt die Prognose nicht nur stark, sondern weist auch am Beginn häufig eine zu geringe RUL aus, während kurz vor der Störung zu viel RUL angegeben wird. Bei dieser Unzuverlässigkeit würde die Instandhaltung entweder

viel zu früh agieren und könnte vielleicht keine Fehler feststellen. Oder es kommt doch zur Störung und zu Verspätungen, weil der Ausfall unerwartet eintritt.

Ein Gesamteindruck zum hier vorgestellten Ansatz ergibt sich, wenn paarweise eine Störung aus der Vergangenheit für das Training des SVM-Modells verwendet wird, um damit eine zukünftige Störung zu prognostizieren. Für die Auswertung in Abb. 5 wird die sogenannte Receiver Operating Characteristic (ROC) bzw. der ROC-Graph verwendet. Dies ist eine Visualisierungsmethode, die für die Leistungsbeurteilung von Klassifizierungen verwendet wird [10]. ROC-Graphen sind eine etablierte Methode für die Beurteilung von Diagnose- und Prognosesystemen [11]. Im ROC-Graphen ist die beste Leistung in der linken oberen Ecke lokalisiert. Dort wird die RUL aller Messungen richtig zugeordnet, während kein Fehlalarm auftritt. Entlang der Diagonalen ist die Prognose nicht besser als zufälliges Würfeln. Unterhalb wäre ein Anwender ohne eine Prognose besser dran, da diese häufiger falsch ist als richtig. Abb. 5 belegt, dass zahlreiche Prognosen zuverlässig sind. Die vielen Punkte in der Nähe der Diagonalen und insbesondere darunter zeigen aber auch, dass der Ansatz noch Grenzen hat und verbessert werden muss.




Abb. 3: Beispiel einer gut funktionierenden RUL-Prognose




Abb. 4: Beispiel einer unzuverlässigen RUL-Prognose




Abb. 5: Qualitätsauswertung aller paarweisen RUL-Prognosen einer zukünftigen Störung anhand einer vergangenen

Welche Grenzen bestehen und wie können sie überwunden werden?

Werden Standard- und Freitexte der Störungsdokumentation im Detail betrachtet, lassen sich Gründe für die Ergebnisse erkennen. Diese manuelle Detailanalyse kann aufgrund der Anzahl von 1830 paarweisen Prognosen zwar nur vereinzelt vorgenommen werden, gibt aber dennoch wichtige Anhaltspunkte. So gelingt eine Prognose dann relativ gut, wenn die beiden Störungen zeitlich relativ dicht beieinander liegen, die betroffenen Weichen einer Gruppe angehören und die Störungsursache eindeutig gleich ist. Bei schlechten Prognosen treten diese Gegebenheiten nicht auf. Wie bereits erwähnt, sind die Dokumentationen der Störungsursachen unpräzise und teilweise sogar widersprüchlich. Zum Beispiel wird als Ursache „Fehlfunktion“ am Bauteil „Schadbild allgemein“ angegeben, oder „keine Endlage“ bei gleichzeitigem Vermerk „Weiche o.k. kein Fehler“. Diese Einträge sind zwar aus Sicht der Instandhaltung berechtigt, hemmen aber eine automatische Verarbeitung, Diagnose oder Prognose.

Die Qualität der Dokumentation ist allerdings nicht das einzige Hindernis für den Ansatz. Dass das Ergebnis bei zeitlich weit auseinander liegenden Störungen nicht gut ist, liegt vermutlich an nicht erfassten Einflussfaktoren. Über die Zeit verschlechtert sich der Weichenzustand aufgrund von Belastungen. Größen wie die kumulierte Achslast, die Liegedauer oder die Anzahl der Überfahrten

können Aufschluss über langfristigen Verschleiß geben. Werden sie mit einbezogen, kann die Prognose verbessert werden. Außerdem waren bei den Stellstrommessungen nur Mittelwerte der Umstellphasen verfügbar, wodurch nicht die Daten der gesamten, unverdichteten Umstellmessung genutzt werden konnten. Doch aus der gesamten Messung können Merkmale mit höherem Informationsgehalt gebildet werden, die differenziertere Aussagen zulassen [12, 13]. Letztlich ist es auch möglich, dass SVM als gewähltes Verfahren noch nicht die optimale Wahl darstellen.

Fazit

Zusammenfassend betrachtet ist der datengetriebene Ansatz, bei dem Weichenstörungen anhand von Stellstrommessungen, Klimadaten und Bauartgruppen mittels Support Vector Machine vorhergesagt werden, vielversprechend. Weitergehende Forschung beschäftigt sich mit der Verbesserung der Ursachendiagnose und -dokumentation, verbesserter Merkmalsextraktion und der Quan-

tifizierung und Integration weiterer zustandsbeeinflussender Größen. Dafür arbeitet das DLR mit der DB AG und zukünftig auch verstärkt mit Strukton als Systemhersteller und Instandhalter zusammen. Auf diese Weise sollen die bestehenden Grenzen des Ansatzes überwunden werden, so dass eine präzise, verlässliche Prognose Weichenstörungen verhindert und die Pünktlichkeit erhöht.

LITERATUR

- [1] Rausch, W.: Diagnosesysteme für Weichen als Grundlage für eine optimierte Instandhaltungsplanung, Symposium zum Thema: Moderne Instandhaltungsverfahren für Weichen – Qualitätsansprüche – Wirtschaftlichkeit, Brandenburg-Kirchmöser, 2010
- [2] Madlinger, D.; Keipert, J.: Instandhaltungsprogramme Südwest, Vortrag zur 13. Fachtagung Leit- und Sicherungstechnik, Bruchsal, DB Netz AG Regionalbereich Südwest, 2013
- [3] Holst, S.: „Lösung zur Instandhaltung signaltechnischer Anlagen“, Deine Bahn, 2/2012, S. 19-23
- [4] Fayyad, U. M.; Piatetsky-Shapiro, G.; Smyth, P.: From Data Mining to Knowledge Discovery in Databases, AI Magazine, 17/1996, S. 37-54
- [5] VDI/VDE, Richtlinie 2651 – Plant Asset Management (PAM) in der Prozessindustrie – Definition, Modell, Aufgabe, Nutzen, Vols. 35.240.50, 71.020, Berlin, Beuth Verlag, 2008
- [6] Stoll, H.; Bollrath, B.: Weichendiagnosesystem SIDIS W, Signal + Draht, 4/2002, S. 26-29
- [7] Böhm, T.; Doegen, C.: Diagnosis without Sensors – Integrati-

on of External Data for Condition Monitoring of Railway Switches, in Comadem 2010 – Advances in maintenance and condition diagnosis technologies towards sustainable society, Hikone (Japan), Sunrise Publishing, 2010, S. 619-622

- [8] Duda, R. O.; Hart, P. E.; Stork, D. G.: Pattern Classification, 2nd ed., s.l.: Wiley-Interscience, 2012
- [9] Burges, C. J. C.: A Tutorial on Support Vector Machines for Pattern Recognition, Data Mining and Knowledge Discovery, vol. 2, S. 121-167, 1998
- [10] Egan, J. P.: Signal Detection Theory and ROC Analysis, New York (NY USA), Academic Press, 1975
- [11] Swets, J. A.: Measuring the accuracy of diagnostic systems, Science, vol. 240, S. 1285-1293, 1988
- [12] Schenkendorf, R.; Böhm, T.: Aspekte einer datengetriebenen zustandsabhängigen Instandhaltung, Teil 1, EI – DER EISENBAHNINGENIEUR 11/2014, S. 14-18
- [13] Schenkendorf, R.; Böhm, T.: Aspekte einer datengetriebenen zustandsabhängigen Instandhaltung, Teil 2, EI – DER EISENBAHNINGENIEUR 3/2015, S. 21-25



Dipl.-Ing.-Inf. Thomas Böhm

Gruppenleiter
Life Cycle Management,
Institut für Verkehrssystemtechnik,
Abteilung Bahnsysteme,
Deutsches Zentrum für Luft- und
Raumfahrt e.V., Braunschweig
thomas.boehm@dlr.de

Zusammenfassung

Präzise Vorhersage von Weichenstörungen

Die präzise Vorhersage der verbleibenden Nutzungsdauer (RUL) ermöglicht es, dass Instandhalter agieren können, bevor der Ausfall auftritt und teure Verspätungen entstehen. Wie eine datengetriebene Prognose im Fall von Weichen erfolgt, zeigt der vorliegende Artikel zur aktuellen Forschung am DLR. Er umreißt, wie Stellstrommessungen des Antriebs, Klimadaten und Bauartcharakteristiken von Weichen genutzt werden, um mithilfe von Data-Mining-Verfahren eine RUL-Aussage abzugeben. Neben zahlreichen guten Prognosen wurden auch viele weniger treffsichere Vorhersagen erzeugt. Dies zeigt, dass der Ansatz vielversprechend ist, aber noch deutlich reifen muss. Vor allem die Datenqualität sowie der extrahierte Informationsgehalt der Messungen müssen erhöht werden, um die Vorhersage zu verbessern.

Summary

Accurate forecast of turnout failures

By an accurate forecast of the remaining useful life (RUL) appropriate maintenance actions can be carried out before a turnout breaks down and produces expensive delays. Based on the current research activities at the DLR (German Aerospace Center) the present article shows how a data driven forecast in the case of turnouts is carried out. It outlines how control current measurements of the drive, climate data and design characteristics of turnouts are processed to provide an RUL with the help of data mining procedures. Apart from numerous correct forecasts, many less accurate forecasts were produced. This shows that the approach is promising but that it still has to mature significantly. It is above all the quality of data as well as the extracted information contents of the measurement that must be increased in order to improve the forecasts.

www.austroroll.at

A - 2551 Enzesfeld, Fabrikstraße 2
Tel. +43 (0) 2256 / 81145
e-Mail: austroroll@buntmetall.at

Rollen statt schmieren!

AUSTROROLL®

Weichenzungen-Rollvorrichtung

- stoßunempfindlich durch dauerhaft elastische Lagerung
- 60% Stellkraftreduktion über gesamten Stellweg
- für Neubau und Nachrüstung
- 5 Jahre Gewährleistung
- kundenspezifische Halterungslösungen
- über 180.000 Rollen im weltweiten Einsatz
- Oberbaustandard (z.B. bei DB-AG, ÖBB)

Buntmetall
Werk Enzesfeld-Caro